Dateien & Dateisysteme

PD Reinhard Bündgen
buendgen@de.ibm.com

Dateien in Unix

- Unix: alles ist eine Datei
  - Datensätze auf Hintergrundspeicher
  - Geräte
  - Netzwerkanschluss (Socket)
  - Kommunikationskanäle (pipes, fifos)
- Operationen auf Dateien
  - open/close, read/write, mmap, select/poll, llseek, fctl, ...
- Organisation von Dateien auf Hintergrundspeichern
  - Hierarchische Organisation der Dateien
    - Verzeichnisse, Dateisystembaum
    - Namespace, Dateisystem (Achtung überladene Bezeichnung)
- Literatur: Stevens & Rago: *Advanced Programming in the UNIX Environment (2nd Ed.)*. Addison-Wsley 2005

Dateitypen in Unix

- - normale Datei
- d Verzeichnis
- c Character Device
- b Blockgerät
- l symbolischer Link
- p FIFO (named pipe)
- pipe
- socket

Dateisystem (DS): Begriffe

- Dateisystemtyp
  - Beschreibt wie Daten organisiert sind
- Dateisystem
  - Sammlung von Daten, die gemäß einem Dateisystemtyp organisiert sind
- Virtuelles DS (VFS)
  - architekturelle Schicht im Kern die von spezifischen DSen und DS-Typen abstrahiert
- Logisches DS, Dateisystembaum, Dateihierarchie, (namespace)
  - Benutzersicht aller adressierbaren Dateien
  - i. A. montiert aus verschiedenen Dateisystemen

Dateisystemtypen (Formate)

- Beschreibt
  - physische Organisation der Daten
  - Zugriffsweg zu Daten (via page cache?)
  - Implementierung der Dateisystem- und Dateioperationen
- Von Linux unterstützt (Auswahl)
  - HW DS:
    - minix, ext2/ext3/ext4, btrfs, reiser, xfs, jfs, vfat, hfs, hpfs, msdos, ntfs
    - formatieren mit `mk`*`xxx`*`fs` Kommando
  - Netzwerk DS
    - nfs, cifs, coda, afs, smbfs
  - Cluster DS
    - ocfs2, gfs2
  - Pseudo DS
    - proc, sys, debug
- Registirerung eines neuen Dateisystemtyps im Kern
  - `int register_filesystem(struct file_system_type * fs)`

Dateisystemmontage

- `mount` Kommando
- `mount()` Systemruf
  - assoziiert formatierte Partition, Pseudo-DS oder NW DS mit Gebiet im logischen DS
  - DS Typ durch Option beschrieben (oft automatisch erkannt)
  - Optionen können weitere Eigenschaften beschreiben
    - Zugriffsautorisierung
    - Synchronisationsverhalten
    - ...
  - `/etc/fstab`
- (Montage) Namespace
  - Prozessspezifische Dateihierarchie

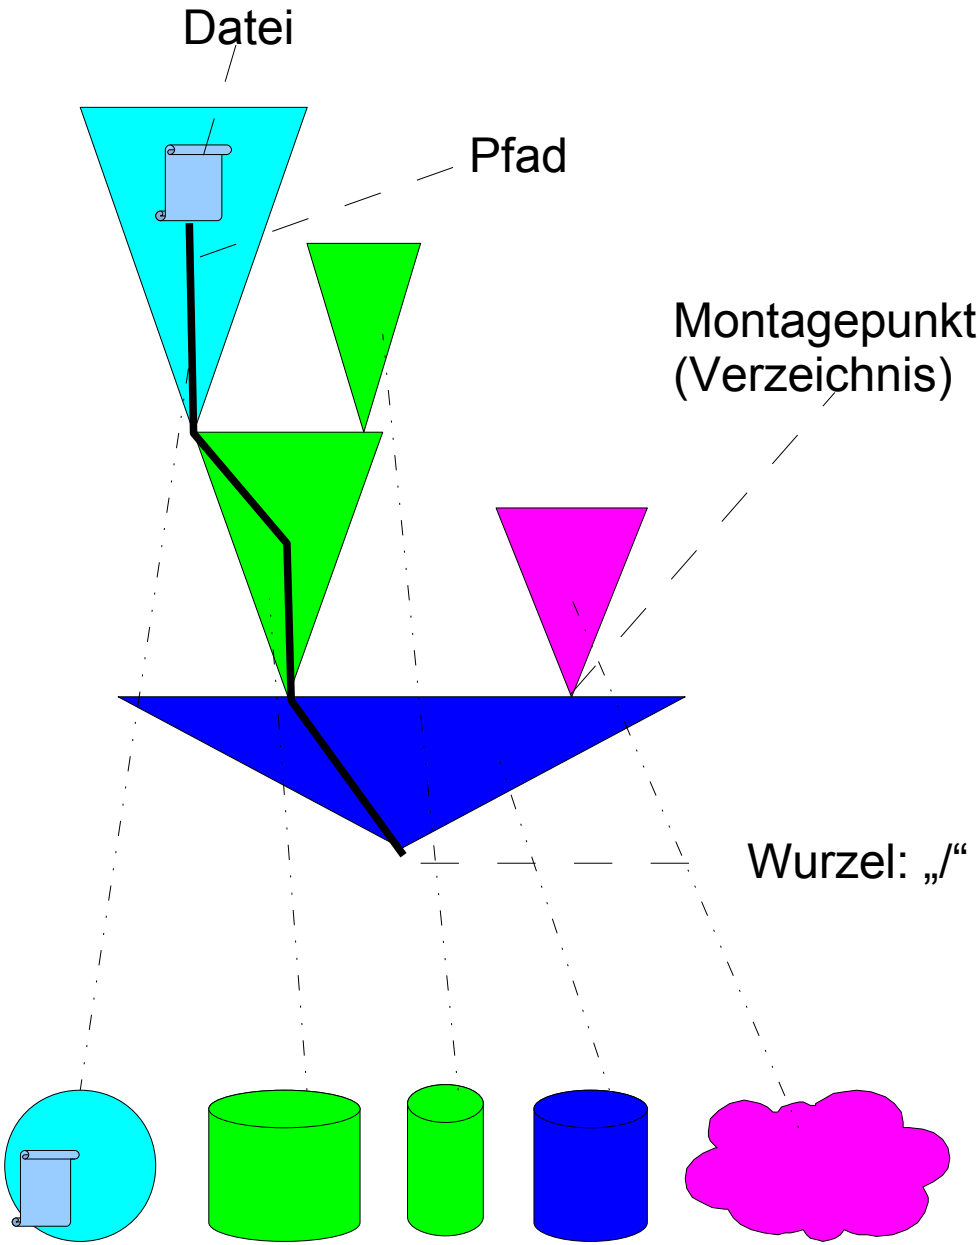

Das Virtuelle File System (VFS)

- Abstraktionsschicht im Kern
  - vermittelt zwischen Nutzerraum und konkreter Dateisystem Implementierung
- Gibt dem Nutzerraum eine einheitliche Schnittstelle auf verschieden Dateisystemtypen
  - stellt Standard Datei Systemrufe zur Verfügung
  - Implementierung der Funktion wird anhand der Dateisystemtypzugehörigkeit der zu manipulierenden Datei bestimmt
  - „objektorientiert“

VFS

Programme können Dateioperationen unabhängig vom Speicherort und -typ nutzen.

```
in=open(„/.../.../.../d1“,O_RDONLY,0);
out=open(„/.../d2“,
      O_WRONLY|O_CREATE|O_TRUNC,0600);
do {
        n = read(in,buf,4096);
        write(out,buf,n);
} while(n);
close(out);
close(in);
```

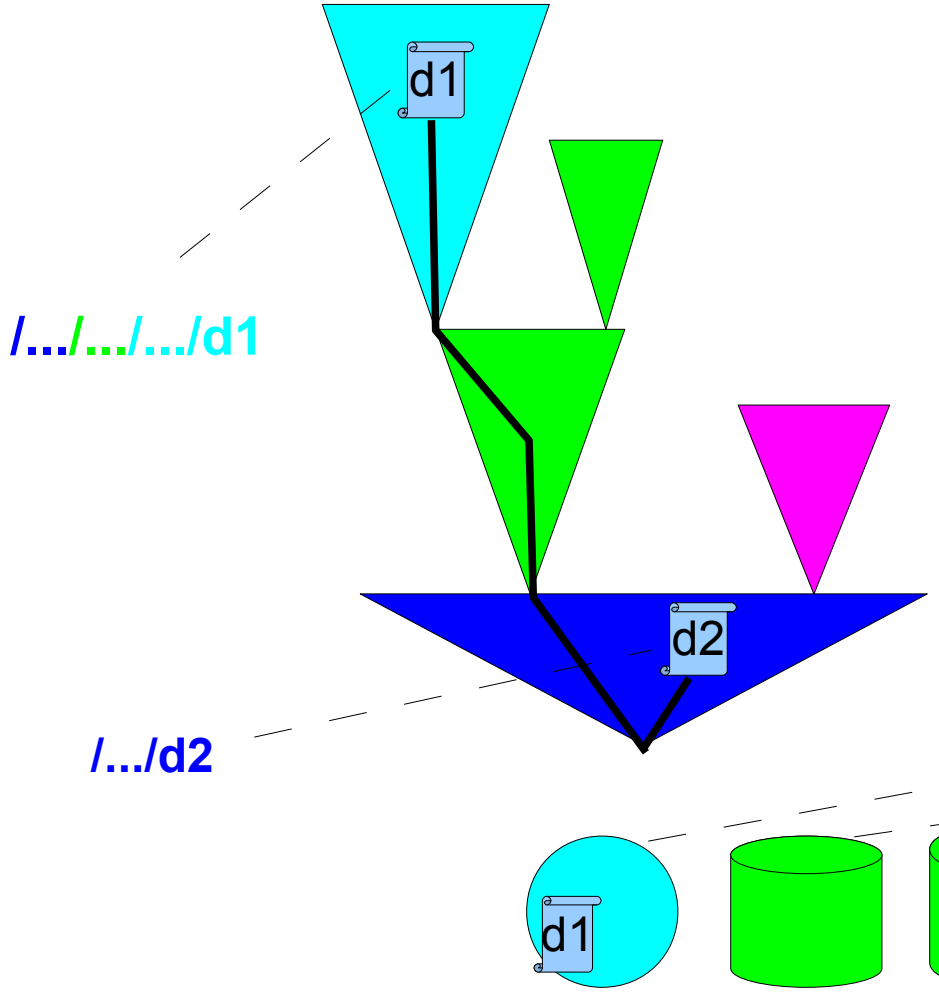

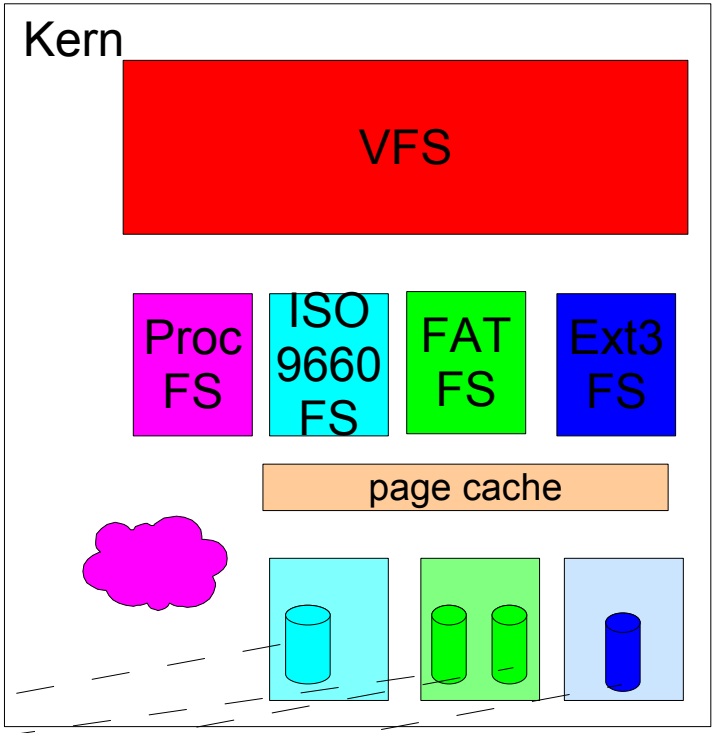

US: write()

VFS: sys_write()

FS: fs_write()

[DD: dd_write()]

Wichtige Objekte im VFS

- das VFS-Superblock-Objekt
  - `struct superblock` (`<linux/fs.h>`)
  - beschreibt montiertes FS, enthält u.a Info aus FS Control Block auf Platte
- das VFS-INode-Objekt
  - `struct inode` (`<linux/fs.h>`)
  - identifiziert Datei im Kern, beschreibt Metadaten einer Datei, enthält u.a. Info aus File Control Block auf Platte (disk inode)
- das Dentry-Objekt
  - `struct dentry` (`<linux/dcache.h>`)
  - assozeiert Pfad mit Datei (Inode), gemäß Pfad ge-hash-t
- das Datei-Objekt (offene Datei)
  - `struct file` (`<linux/fs.h>`)
  - beschreibt Zustand einer offenen Datei einer Task

Wie hängen die Strukturen zusammen?

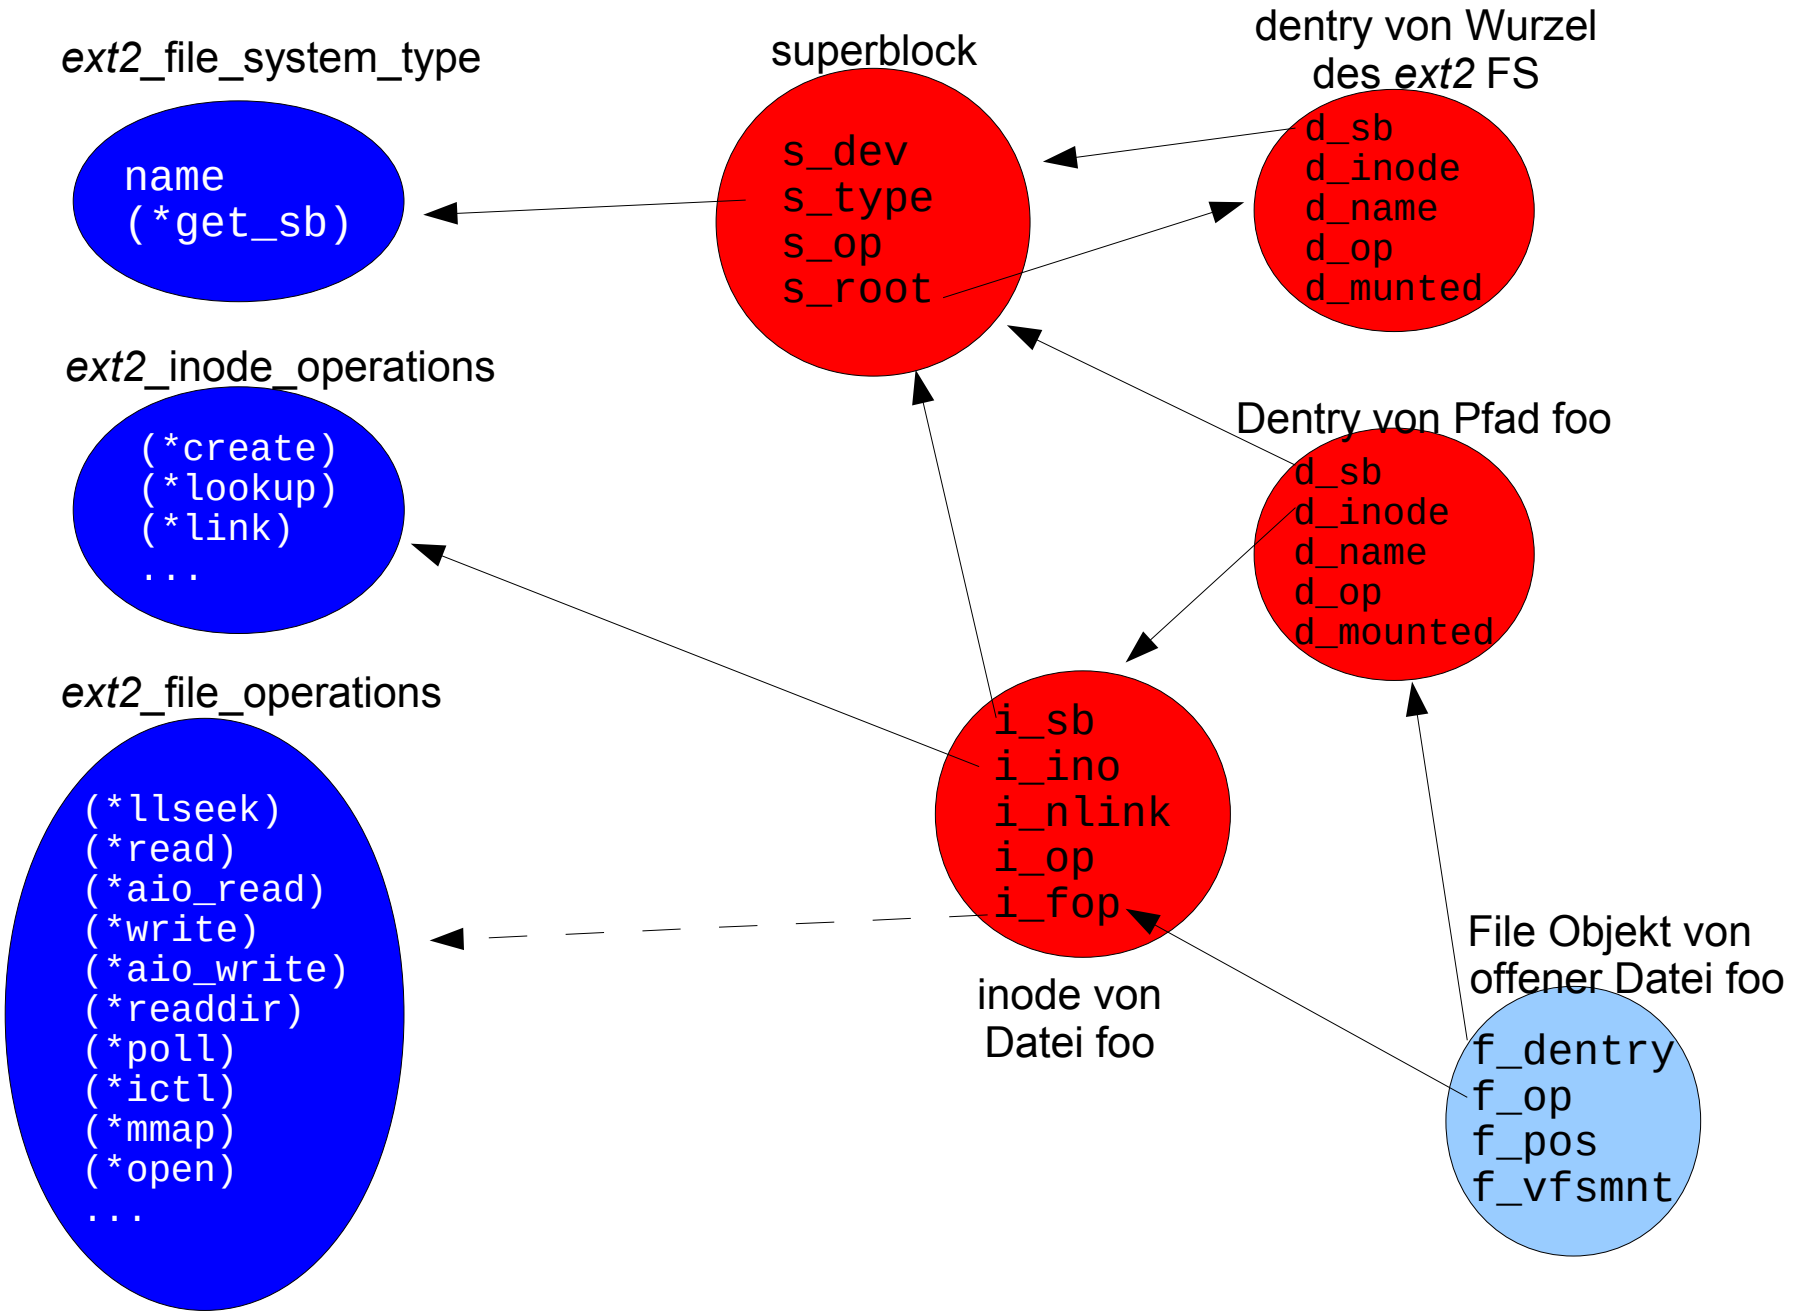

DS Montage im Kern

DS Montagen sind namespace spezifisch

- `struct mnt_namespace`
- in `task_struct->nsproxy`

Beschrieben in Montageobjekt

- `struct vfsmount` (`<linux/mount.h>`):
  - Elterndateisystem
  - Kinderdateisysteme
  - Montagepunkt
  - Wurzel
  - Superblock
  - Namespace

Prozess spezifisch:

- `struct fs_struct` (`task_struct->fs`)
  - Enhält Montageobjekte für Wurzel und laufendes Verzeichnis

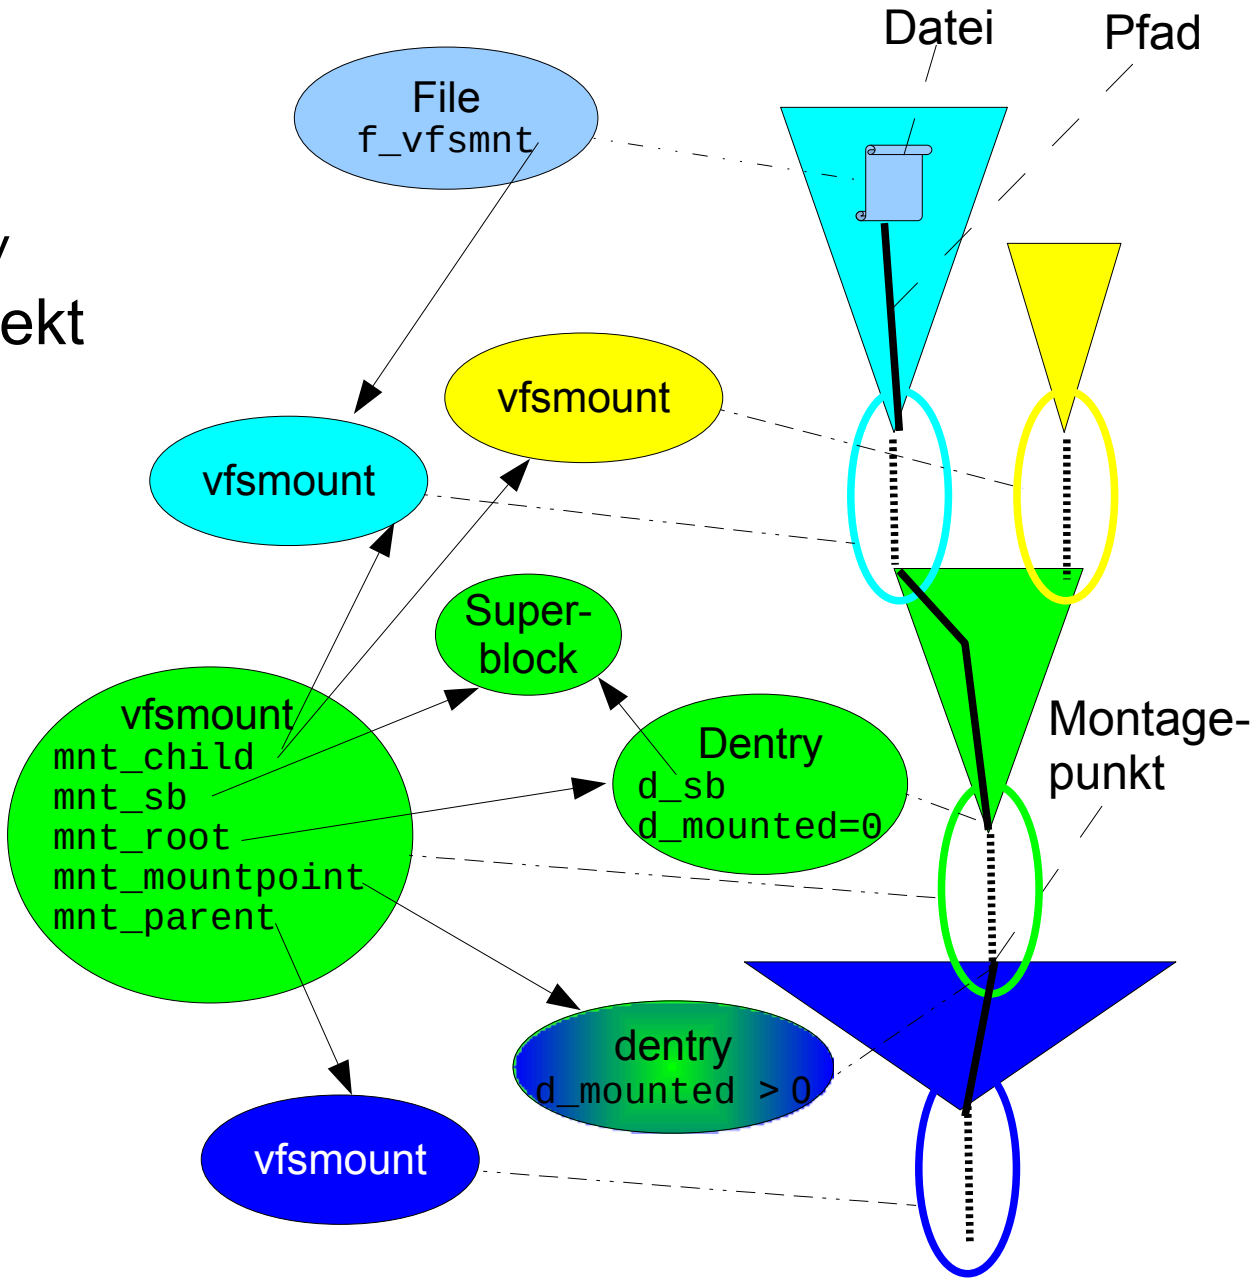

Offene Dateien in Unix

`fd=open(path, ...)` assoziiert Pfad `path` mit Dateibezeichner `fd`

`dup(fd)` erzeugt Kopie eines Dateibezeichners

`fork()` kopiert alle Dateibezeichner des Vaterprozesses (file sharing)

Dateibezeichner Flags: FD_CLOEXEC

File Status: open()-Flags

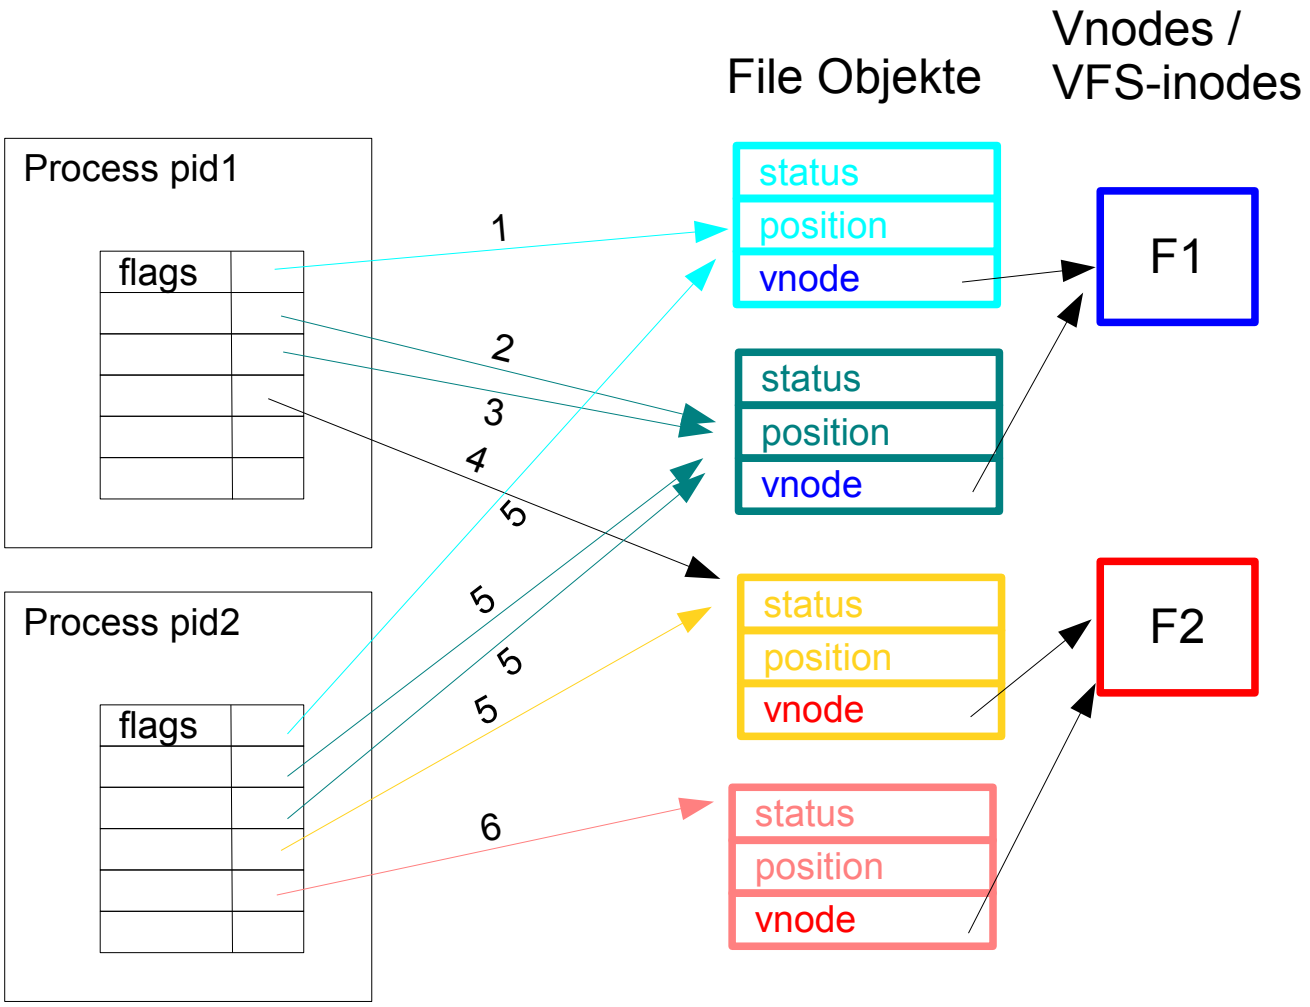

1. Process pid1: fd0=open(F1,...);
2. Process pid1: fd1=open(F1,...);
3. Process pid1: fd2=dup(fd1);
4. Process pid1: fd3=open(F2,...);
5. Process pid1: pid2=fork();
6. Process pid2: fd4=open(F2,...);

Repräsentation von Dateien

- User:
  - Pfad, Dateiname, Dateityp
- Prozess (offene Datei)
  - Dateibezeichner (fd)
- Kerntasks (offene Datei)
  - File Descriptor Array, Fileobjekt
- Kern
  - inode object, dentry
- Physisch (auf Partition)
  - Disk inode

Wie passt alles zusammen?

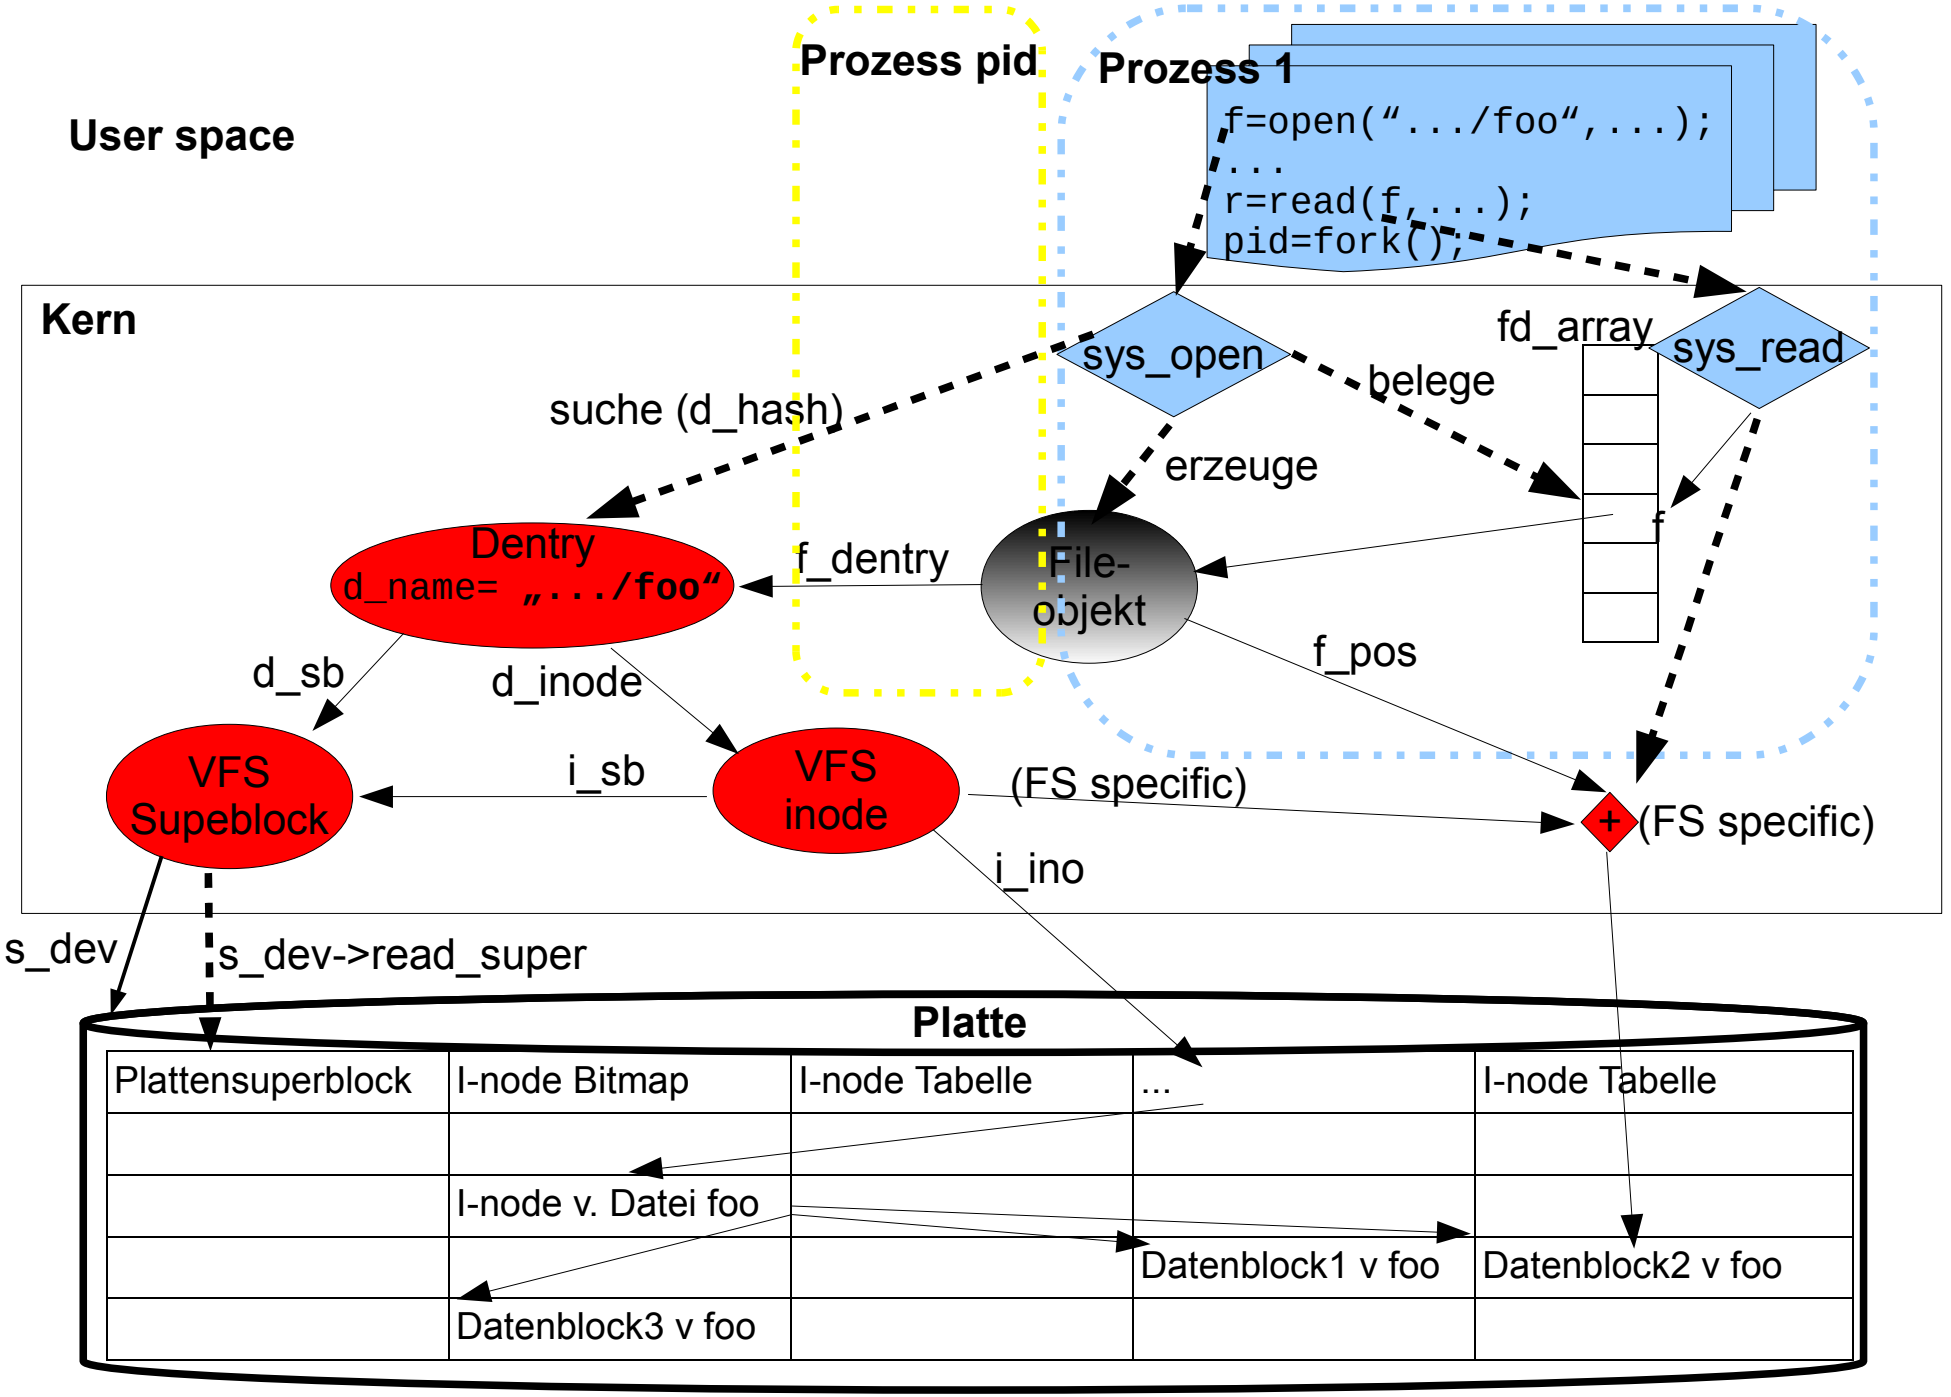

Filesystem in user space (FUSE)

FUSE Komponenten

- fuse.ko Modul
- libfuse
- fusermount

User Space FUSE Dämon

- Liest fuse Anfragen von fuse Gerät
  - `/dev/fuse`

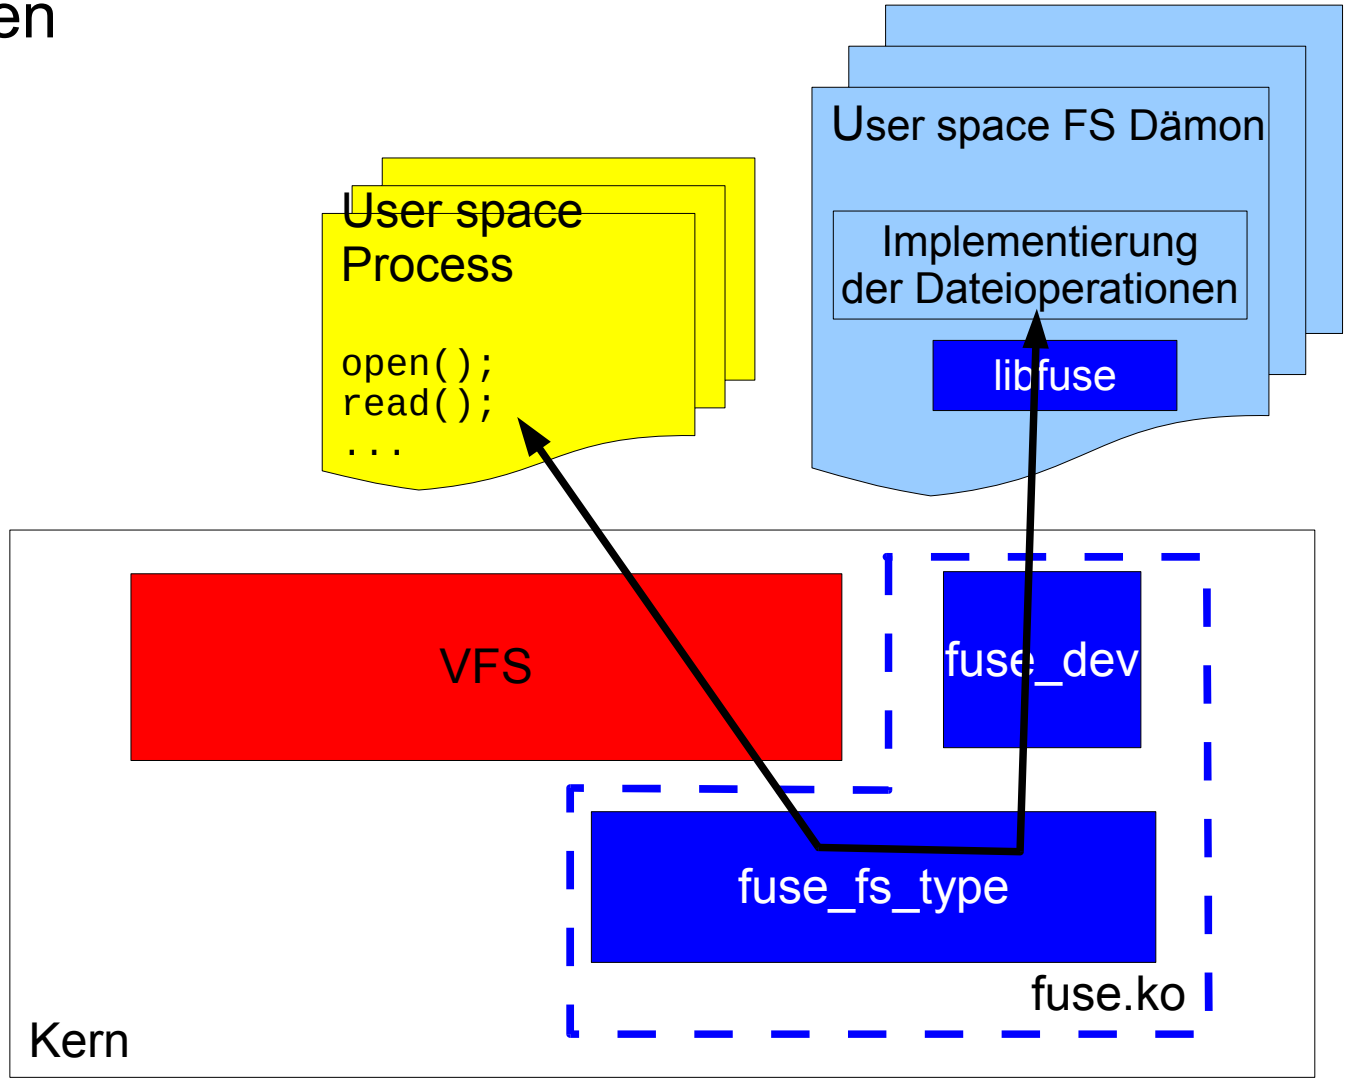

Besondere Dateisysteme

- File System Check / Journaling
  - Metadaten / Daten
- Dynamische Veränderung der Größe
- Verteilte DS, Netzwerk DS
- Cluster DS
- User Space DS
- Crypto DS
- Device backed / Pseudo DS
- Nutzung von page cache oder nicht